

## PENGEMBANGAN MODEL PREDIKSI OLR-MJO BERBASIS HASIL ANALISIS MODEL STATISTIK BOX-JENKINS (ARIMA)

Eddy Hermawan

*Bidang Pemodelan Iklim Pusat Pemanfaatan Sains Atmosfer dan Iklim LAPAN  
Jln. Dr. Djundjuran 133, Bandung 173  
E-mail : eddy\_lapan@yahoo.com*

### Abstrak

Studi ini menekankan pentingnya pengembangan model prediksi *Madden-Julian Oscillation* (MJO) sebagai osilasi (embutan) dominan yang ada di kawasan Indonesia dan sekitarnya. Banyak metode yang digunakan, mulai yang berbasis dinamik, statistik ataupun kombinasi keduanya. Pada makalah ini, kami lebih memfokuskan kepada penggunaan metode analisis deret waktu (time-series) statistik Box-Jenkins dalam memprediksi perubahan atau fluktuasi besarnya radiasi gelombang panjang (dikenal sebagai OLR = Outgoing Longwave Radiation) sebagai salah satu parameter penting dalam memprediksi terjadinya MJO di atas kawasan Indonesia. Analisis metode ini dibagi dalam tiga tahap, yaitu : identifikasi model, penaksiran parameter dan uji diagnostik yang digunakan untuk menganalisis data deret waktu stasioner maupun tidak stasioner. Kenyataan yang ada menunjukkan bahwa data time-series yang dianalisis, umumnya tidaklah bersifat stasioner (membentuk pola atau keteraturan tertentu). Padahal ini adalah syarat utama yang harus dipenuhi, bila kita ingin membuat model prediksinya. Oleh karena itu, maka perlu dilakukan *differencing* atau transformasi untuk menstasionerkan data time-series tadi. Sebagai salah satu parameter utama dalam mengkaji fenomena MJO, maka dalam studi ini, digunakan data anomali pentad OLR (dalam satuan  $\text{Watt/m}^2$ ) yang berada di atas kawasan Indonesia, mulai dari  $100^\circ$  BT,  $120^\circ$  BT, dan  $140^\circ$  BT periode 3 Januari 1978 hingga 12 Juni 1980. Awalnya, ini merupakan data time-series OLR yang tidak stasioner. Setelah melalui tahapan analisis Box-Jenkins, maka model ARIMA yang cocok untuk posisi  $100^\circ$  BT dan  $120^\circ$  BT adalah sama, yakni ARIMA (2,1,1), sementara untuk posisi  $140^\circ$  BT adalah ARIMA (1,1,2). Informasi lebih lanjut tentang model Box-Jenkins yang digunakan, termasuk tahapan analisis yang dipakai dan berapa lama model tadi valid untuk dapat diterapkan, akan kami bahas dalam makalah ini.

**Kata kunci :** MJO, OLR, dan Box-Jenkins-ARIMA

### Abstract

This study is mainly concerned for developing the *Madden-Julian Oscillation* (MJO) prediction is one of the most pre dominant oscillation over Indonesia and surrounded area. There many methods are used now, from the dynamic, statistic, or comination between of them. In this paper, we mainly focussed on the Box-Jenkins analysis of the variability or the fluctuation of *Outgoing Longwave Radiation* (OLR) as one of the most important parameter in predicting the MJO phenomena over Indonesia and surrounded area. This method analysis is divided into three steps : an identifiaion of the model, estimated parameter, and diagnostic analysis that generally is used for detecting the stationer or non stationer of one set data analysis. In the fact , usuallly we find that one of time-series data analysis is nonstationer. Beside, it is very important when we would like to make a prediction. So, we need to make differencing or transformation to change from non stationer to stationer data analysis. Since OLR is defined as one of the most important parameter for detecting the MJO phenomena, in this present study, we applied the pentad OLR anomaly over  $100^\circ$  E,  $120^\circ$  E, and  $140^\circ$  E, respectively, for period of January 3, 1978 to June 12, 1980. Since OLR is nonstationary time series, we transformed into stationary time-series data analysis. Then, we found that for  $100^\circ$  E and  $120^\circ$  E is same ARIMA (2,1,1), while, for  $140^\circ$  E is ARIMA (1,1,2). Detailed informations of the Box-Jenkins method analysis including the steps, and for how long that model can be valid will be discussed in this paper.

**Keywords :** MJO, OLR, dan Box-Jenkins

## 1. PENDAHULUAN

Indonesia merupakan satu-satunya kawasan maritim di daerah ekuator yang dua per tiga wilayah didominasi oleh lautan, sehingga wilayah ini memiliki posisi yang sangat unik yang menyebabkan cuaca dan iklim Indonesia dipengaruhi oleh sirkulasi atmosfer, baik skala global, regional maupun lokal. Diantara parameter iklim, curah hujan merupakan parameter yang penting. Besarnya variabilitas curah hujan di Indonesia baik dalam skala ruang dan waktu, umumnya disebabkan oleh dinamika aktif dari kumpulan awan-awan Cumulonimbus (Cb) yang dikenal dengan istilah *Super Cloud Cluster* (SCC), seperti yang dilakukan oleh Matthews (2000) ketika menganalisis perilaku atau dinamika SCC tadi dengan menggunakan data radiasi gelombang panjang (*Outgoing Longwave Radiation*, OLR).

Kumpulan awan yang terbentuk di Samudera Hindia tadi umumnya bergerak ke arah timur (*eastward*), dan membentuk pola atau osilasi tertentu yang kemudian dikenal dengan istilah *Madden Julian Oscillation* (MJO). MJO paling jelas terlihat pada variasi radiasi OLR yang diukur dengan sebuah sensor infra merah pada sebuah satelit yang mengambil pengukuran dari karakter radiatif energi yang diradiasi dari pemanasan permukaan bumi ke pendinginan angkasa. Pengukuran ini memberikan informasi mengenai suhu puncak awan yang dapat digunakan untuk memperkirakan jumlah hujan tropis yang akan jatuh di salah satu kawasan tertentu.

Terkait dengan fenomena di atas, seringkali ditemukan data yang tidak stasioner yang menyebabkan gagalnya suatu model dibuat atau dikembangkan. Banyak metode yang digunakan untuk menjadikan suatu data time-series yang semula tidak stasioner menjadi stasioner. Satu diantaranya adalah metode Box-Jenkins atau yang lebih dikenal dengan istilah ARIMA (*AutoRegressive Integrated Moving Average*).

Atas dasar itulah, maka paper ini dibuat dengan tujuan utamanya memberikan gambaran yang jelas mengenai penggunaan model deret waktu Box-Jenkins, khususnya ARIMA dalam memodelkan data anomali pentad OLR, selain menduga besarnya radiasi gelombang panjang (OLR) yang bakal terjadi di waktu mendatang.

## 2. DASAR TEORI

### 2.1. Karakteristik Iklim di Indonesia

Iklim di Indonesia, yang secara geografis merupakan benua maritim, dicirikan oleh keragaman curah hujan yang cukup besar antar daerah. Selain mendapat pengaruh dari sirkulasi udara pada skala global maupun regional, pembentukan awan dan hujan di Indonesia juga dipengaruhi kondisi local, seperti topografi dan suhu permukaan laut di perairan Indonesia.

Karakteristik iklim, khususnya hujan dapat dianalisis secara akurat berdasarkan data iklim dari stasiun meteorologi. Namun untuk analisis spasial, hal ini sangat ditentukan oleh kerapatan jaringan penakar hujan. Untuk daerah-daerah dengan jaringan penakar hujan yang cukup rapat dan merata hal tersebut tidak menjadi masalah. Namun dengan kondisi Indonesia yang terdiri dari berbagai macam propinsi yang terentang pada posisi  $95^{\circ}$  BT -  $141^{\circ}$  BT, terlihat bahwa kerapatan jaringan penakar hujan tidak sama untuk seluruh propinsi.

Salah satu alternatif untuk menganalisis karakteristik iklim secara spasial adalah dengan data OLR. Hal ini karena OLR merupakan radiasi gelombang panjang yang dipancarkan oleh permukaan bumi dan besarnya sangat dipengaruhi oleh kondisi atmosfer terutama awan karena jumlahnya relatif cukup besar dan sangat dinamis dibandingkan bahan-bahan penyerap OLR lainnya di atmosfer.

### 2.2. Pengertian Data Deret Waktu

Data deret waktu adalah himpunan observasi yang dibangun berurutan dalam waktu. Notasi  $Z_t$  berarti observasi pada waktu  $t$ . Waktu  $t$  bisa merupakan tahun, bulan, hari, jam atau waktu lainnya tergantung situasi. Karena akan memodelkan himpunan observasi yang penuh dengan ketidakpastian, maka diasumsikan untuk setiap waktu  $t$ ,  $Z_t$  adalah variabel acak.

Rangkaian dari variabel acak  $\{Z_1, Z_2, \dots\}$  atau  $\{\dots, Z_{-1}, Z_0, Z_1, Z_2, \dots\}$  dinamakan proses stokastik (Cryer, 1986: 9). Terdapat dua macam data deret waktu, yaitu:

1. Deret waktu diskrit, yaitu suatu deret waktu dimana himpunan  $T_0$  dari waktu ke waktu pengamatan dilakukan dengan himpunan diskrit, seperti harian, bulanan, dan lain-lain.
2. Deret waktu kontinu, yaitu data yang diperoleh jika observasi dicatat pada suatu interval waktu tertentu. Misalnya dalam interval lima menit atau  $T_0 = [0, 5]$ .

Observasi  $z(t)$  diasumsikan sebagai suatu nilai (realisasi) dari suatu variabel acak  $Z(t)$ . Sebagai contoh, banyaknya bintang matahari tahun 1850 dipandang sebagai  $Z(t)$ , setelah dilakukan observasi didapat  $z(t)$  yang merupakan realisasi dari variabel acak  $Z(t)$ . Dengan demikian deret waktu  $\{z(t), t \in T_0\}$  adalah suatu realisasi dari variabel acak  $\{Z(t), t \in T_0\}$ . Perilaku  $Z(t)$  ditentukan oleh distribusi peluang.

### 2.3. Model Deret Waktu Tidak Stasioner : ARIMA

Tidak selamanya data yang akan dianalisis akan menunjukkan kestasioneran. Data yang tidak stasioner seringkali didapatkan di kehidupan nyata. Deret waktu tanpa mean yang konstan misalnya, termasuk tidak stasioner. Salah satu cara menstasionerkan data adalah melalui *differencing* (pembedaan). Tinjau model AR (1):

$$Z_t = \phi Z_{t-1} + a_t \quad (2.1)$$

Terlihat dari persamaan (2.1) bahwa  $a_t$  tidak berkorelasi dengan  $Z_{t-1}, Z_{t-2}, \dots$ . Agar solusinya stasioner memenuhi persamaan (2.19) haruslah  $-1 < \phi < 1$ . Jika  $\phi = 1$ , maka persamaan (2.1) menjadi

$$Z_t = Z_{t-1} + a_t \quad (2.2)$$

atau

$$\nabla Z_t = a_t \quad (2.3)$$

dimana  $\nabla Z_t = Z_t - Z_{t-1}$  adalah pembedaan pertama dari  $Z$ .

Proses stasioner dapat diperoleh dari hasil pembedaan data yang tidak stasioner. Variabel acak  $\{Z_t\}$  dikatakan model integrasi autoregresif-moving average jika dibedakan sebanyak  $d$  kali dan merupakan proses ARMA yang stasioner. Disingkat ARIMA (p,d,q). Biasanya tingkat pembedaannya  $d=1$  atau 2. Secara umum persamaan untuk model ARIMA (p,1,q),

$$W_t = \phi_1 W_{t-1} + \phi_2 W_{t-2} + \dots + \phi_p W_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (2.4)$$

dimana  $W_t = Z_t - Z_{t-1}$ , sehingga

$$\begin{aligned} Z_t - Z_{t-1} = & \phi_1 (Z_{t-1} - Z_{t-2}) + \phi_2 (Z_{t-2} - Z_{t-3}) + \dots \\ & + \phi_p (Z_{t-p} - Z_{t-p-1}) + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \end{aligned} \quad (2.5)$$

Sehingga model ARIMA (1,1,1) memenuhi persamaan:

$$(1-B)(1-\phi_1 B)Z_t = (1-\theta_1 B)a_t \quad (2.6)$$

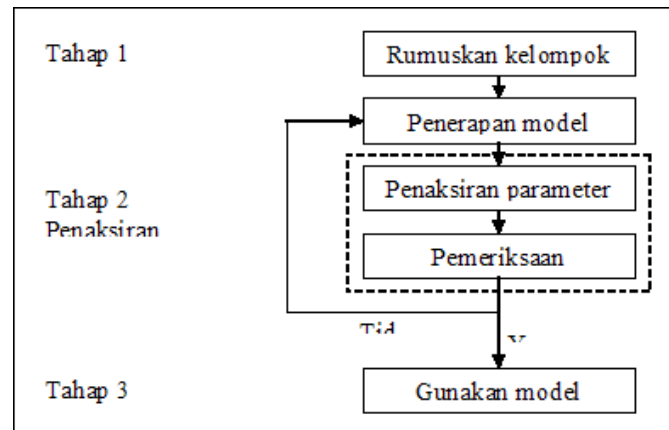
### 2.4. Penaksir Parameter Metode Maksimum Likelihood

Untuk suatu himpunan observasi  $Z_1, Z_2, \dots, Z_n$ , fungsi likelihood  $L$  didefinisikan sebagai peluang (padat) yang diperoleh dari data yang diobservasi. Untuk model ARIMA,  $L$  merupakan fungsi dari  $\phi, \theta, \mu$  dan  $\sigma_a^2$  yang didapat dari observasi  $Z_1, Z_2, \dots, Z_n$ . Penaksir maksimum likelihood kemudian didefinisikan sebagai kemungkinan nilai-nilai parameter dimana data diobservasi yaitu nilai dari fungsi maksimum likelihood.

Ide umum yang melatar belakangi maksimum likelihood adalah sebagai berikut. Misalkan  $f(z, \theta)$  merupakan fungsi kepadatan (*density function*) dari variabel acak  $X$ , dan misalkan  $\theta$  merupakan parameter fungsi kepadatan. Kalau diamati suatu sampel acak  $Z_1, Z_2, \dots, Z_n$ , maka penaksir maksimum likelihood dari  $\theta$  adalah nilai  $\theta$  yang mempunyai probabilitas terbesar untuk menghasilkan sampel yang diamati. Dengan kata lain, taksiran maksimum likelihood dari  $\theta$  adalah nilai yang memaksimumkan fungsi kepadatan  $f(z, \theta)$ .

### 3. DATA DAN METODE ANALYSIS

Data yang digunakan adalah data OLR dari tanggal 3 Januari 1978 hingga 13 April 1981. Sementara tahapan metode analisis yang dipakai tertera dalam Diagram berikut.



**Diagram 3-1:** Skema yang memperlihatkan

Lebih jelasnya, Box dan Jenkins (1976) menjelaskan tahap-tahap yang harus dilaksanakan dalam analisa data deret waktu, yaitu terdiri dari:

#### 3.1. Identifikasi Model

Dalam identifikasi model, hal pertama yang harus dilakukan adalah: (a). Membuat plot data (*time plot*) yang bermanfaat untuk melihat secara kasat mata apakah data stasioner atau tidak, (b). Memeriksa plot dari fungsi autokorelasi (ACF) dan fungsi autokorelasi parsial (PACF) untuk melihat model dari data.

Apabila ACF signifikan pada lag (*lead time*)  $q$  dan PACF menurun secara eksponensial, maka data dapat dimodelkan dengan model moving average derajat  $q$  (MA ( $q$ )) dan jika ACF turun secara eksponensial dan PACF signifikan pada lag  $p$ , maka data dapat dimodelkan dengan model autoregresif derajat  $p$  (AR ( $p$ )). Apabila kedua hal tersebut tidak diperoleh, ada kemungkinan model merupakan proses gabungan AR dan MA atau ARMA ( $p, q$ ).

Jadi untuk menentukan orde dari proses AR adalah dengan melihat PACF. Lain halnya dengan model MA untuk menentukan orde dari model ini digunakan ACF. Namun baik ACF maupun PACF dari masing-masing model harus tetap diperhatikan karena bisa saja model yang diperoleh adalah model ARMA. Oleh karena itu untuk mengidentifikasi model deret waktu lebih baik digunakan kedua-duanya yaitu ACF dan PACF. Berikut ini adalah perilaku ACF dan PACF untuk model AR ( $p$ ), MA ( $q$ ), dan ARMA ( $p, q$ ):

**Tabel 3-1:** Identifikasi Model Deret Waktu AR ( $p$ ), MA ( $q$ ), dan ARMA ( $p, q$ )

	AR ( $p$ )	MA ( $q$ )	ARMA ( $p, q$ )
ACF	Ekspensial menurun	Cut – off pada lag ke- $q$	Ekspensial menurun mulai lag ke - $p$
PACF	Cut – off pada lag ke - $p$	Ekspensial menurun	Ekspensial menurun mulai lag ke - $q$

Perlu digarisbawahi bahwa kebanyakan deret waktu bersifat tidak stasioner dan bahwa aspek-aspek AR dan MA dari model ARIMA hanya berkenaan dengan deret waktu yang stasioner. Jika dari *time plot* tersebut deret terlihat tidak stasioner maka perlu dilakukan pembedaan (*differencing*) untuk menghilangkan ketidakstasionerannya.

### 3.2. Penaksiran Parameter Model

Setelah berhasil menetapkan identifikasi model sementara, selanjutnya parameter-parameter AR dan MA harus ditetapkan. Karena bekerja pada data, maka parameter-parameter yang ada dalam setiap model tidak tercipta dengan sendirinya melainkan berasal dari data yang ada. Terdapat dua cara yang mendasar untuk mendapatkan parameter-parameter tersebut:

1. Dengan cara mencoba-coba (*trial and error*) yaitu menguji beberapa nilai yang berbeda dan memilih satu nilai tersebut (atau sekumpulan nilai, apabila terdapat lebih dari satu parameter yang akan ditaksir) yang meminimumkan jumlah kuadrat nilai sisa/ nilai galat (*sum of squared residuals*).
2. Perbaikan secara iteratif yaitu memilih taksiran awal dan kemudian membiarkan program komputer memperhatikan penaksiran tersebut secara iteratif.

### 3.3. Uji Diagnostik

Setelah berhasil menaksir nilai-nilai parameter dari model ARIMA yang ditetapkan sementara, selanjutnya perlu dilakukan pemeriksaan/ uji diagnostik untuk membuktikan bahwa model tersebut cukup memadai. Cara yang mendasar dalam uji diagnostik ini pertama adalah dengan mempelajari nilai sisa/ nilai galat (*residual*) untuk melihat apakah masih terdapat beberapa pola yang belum diperhitungkan. Nilai galat (*kesalahan*) yang tertinggal sesudah dilakukan pencocokan model ARIMA, diharapkan hanya merupakan gangguan random. Oleh karena itu, apabila plot fungsi autokorelasi dan autokorelasi parsial dari nilai galat telah diperoleh, diharapkan:

1. Tidak ada autokorelasi yang signifikan.
2. Tidak ada autokorelasi parsial yang signifikan.

Kedua yaitu dengan mempelajari statistik sampling dari pemecahan optimum untuk melihat apakah model tersebut masih dapat disederhanakan. Asumsi-asumsi statistik yang mendasari model umum ARIMA, memberikan beberapa angka statistik yang harus dihitung setelah nilai-nilai koefisien optimum diukur. Misalnya saja, untuk setiap koefisien/ nilai parameter yang diperoleh akan terdapat galat sehingga bisa dihitung jumlah kuadrat nilai galat. Nilai koefisien yang terpilih adalah yang memiliki jumlah kuadrat nilai galat terkecil. Nilai galat dapat diperoleh dari:

$$a_t = X_t - \hat{X}_t \quad (3.1)$$


### 3.4. Forecasting (Prakiraan)

Langkah selanjutnya yaitu melakukan prakiraan (*forecasting*) jika model sudah cocok.


## 4. HASIL DAN PEMBAHASAN

### 4.1. Posisi 100 BT

Plot data (*time plot*), ACF dan PACF untuk posisi 100° BT sebagai berikut :




**Gambar 4-1:** Plot Posisi 100° BT



**Gambar 4-2 :** Fungsi Autokorelasi Data Anomali OLR Posisi 100° BT

Gambar 4-1 di atas memperlihatkan bahwa pola data time series menunjukkan pola yang stasioner terhadap rata-rata. Gambar 4-2 memperlihatkan bahwa ACF signifikan pada lag 1, 3, 4, 5, 9, 10 dan 11. Namun karena signifikansi pada lag 3, 4, 5, 9, 10 dan 11 bukan merupakan suatu pengulangan, tapi lebih merupakan random, maka model yang mencerminkan Gambar 4-1 bisa disederhanakan menjadi model moving average orde 1(MA (1)).



**Gambar 4-3 :** Fungsi Autokorelasi Parsial Data Anomali OLR Posisi 100° BT

Gambar 4-3 memperlihatkan bahwa PACF terdapat dua koefisien yang signifikan, yaitu pada lag 1 dan 2, sehingga dapat dikatakan bahwa model dari data tersebut autoregresif berorde 1(AR(1)) atau orde 2(AR(2)). Dengan demikian model yang cukup mewakili dari plot data OLR

pada posisi 100° BT merupakan campuran dari autoregresif dan moving average yaitu ARMA(1,1) atau ARMA(2,1).

Bentuk model ARMA(1,1):

$$(1 - \phi_1 B)Z_t = (1 - \theta_1 B)a_t$$

Bentuk model ARMA(2,1):

$$(1 - \phi_1 B - \phi_2 B^2)Z_t = (1 - \theta_1 B)a_t$$

Seperti telah dijelaskan di atas bahwa salah satu cara yang mendasar untuk mendapatkan parameter adalah dengan mencoba-coba (*trial and error*), yaitu menguji beberapa nilai berbeda dan memilih satu nilai yang meminimumkan jumlah kuadrat nilai galat, maka diperoleh satu nilai parameter yang tepat, yaitu parameter dengan model ARMA(2,1) pada Tabel 4-1 berikut ini.

**Tabel 4-1 :** Parameter  $\phi_1, \phi_2$  dan  $\theta_1$  untuk Model ARMA(2,1)

		Estimates	Std Error	t	Approx Sig
Non-Seasonal	AR1	.775	.110	7.070	.000
Lags	AR2	-.463	.090	-5.134	.000
	MA1	-.272	.121	-2.243	.026
Constant		-.005	.094	-.054	.957

Dengan koefisien :

$$\phi_1 = 0.775 \quad ; \quad \phi_2 = -0.463 \quad ; \quad \theta_1 = -0.272$$

Maka model ARMA(2,1) menjadi


$$\hat{Z}_t = 0.775Z_{t-1} - 0.463Z_{t-2} + 0.272a_{t-1} \quad (4.1)$$

Dengan menggunakan model ARMA(2,1) pada persamaan 4.1 akan diperoleh nilai prakiraan. Lebih jelasnya perbandingan data asli, nilai prakiraan dan nilai galat terlihat pada Tabel 4-2.


**Tabel 4-2:** Perbandingan Data Asli, Nilai Prakiraan, dan Nilai Galat OLR Posisi 100° BT

No	PENTAD	$Z_t$	$\hat{Z}_t$	$a_t$	$a_t^2$
1	19780103	-0,16	-	-	-
2	19780108	1,1	-	-	-
3	19780113	1,03	0,93	0,10	0,01
4	19780118	-1,73	0,32	-2,05	4,19
5	19780123	-2,12	-2,37	0,25	0,06
6	19780128	-0,94	-0,77	-0,17	0,03
7	19780202	0,87	0,21	0,66	0,44
8	19780207	2,41	1,29	1,12	1,26
9	19780212	0,65	1,77	-1,12	1,25
10	19780217	-0,07	-0,92	0,85	0,72
.	.	.	.	.	.
.	.	.	.	.	.
.	.	.	.	.	.
175	19800523	-0,32	-0,22	-0,10	0,01
176	19800528	0	-0,35	0,35	0,12
177	19800602	-0,05	0,24	-0,29	0,09
178	19800607	0,08	-0,12	0,20	0,04
179	19800612	0,51	0,14	0,37	0,14
	JKG				80,62


Plot nilai galat, ACF dan PACF terlihat pada gambar berikut.



**Gambar 4-4 : Plot Nilai Galat**




**Gambar 4-5: Fungsi Autokorelasi Nilai Galat**



**Gambar 4-6 : Fungsi Autokorelasi parsial Nilai Galat**





**Gambar 4-7 : Histogram Nilai Galat**

Gambar 4-5 dan Gambar 4-6 memperlihatkan tidak adanya lagi autokorelasi dan autokorelasi parsial yang signifikan. Gambar 4-7 memperlihatkan bahwa nilai galat berdistribusi normal dengan mean disekitar nol yaitu -0.0047 dan Tabel 4-2 memperlihatkan bahwa jumlah kuadrat nilai galat data OLR posisi 100° BT sebesar 80.62. Ini berarti semua asumsi dalam uji diagnostik sudah memenuhi, sehingga persamaan 4.1 bisa digunakan dalam langkah selanjutnya yaitu memprakirakan besarnya anomali OLR pada lima harian berikutnya.

Dari model yang telah didapat pada persamaan 4.1, maka diperoleh prakiraan untuk tanggal 17 Juni 1980 adalah sebagai berikut

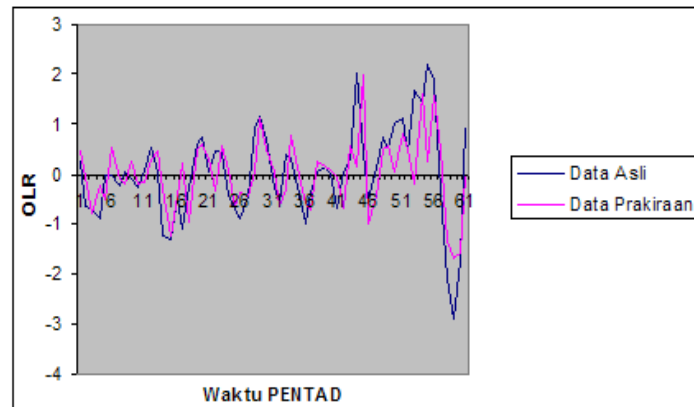
$$\begin{aligned}\hat{Z}_t &= 0.775Z_{t-1} - 0.463Z_{t-2} + 0.272a_{t-1} \\ \hat{Z}_{180} &= 0.775Z_{179} - 0.463Z_{178} + 0.272a_{179} \\ \hat{Z}_{180} &= 0.775(0.51) - 0.463(0.08) + 0.272(0.37) \\ \hat{Z}_{180} &= 0.46\end{aligned}$$

Prakiraan lima harian dari tanggal 17 Juni 1980 sampai tanggal 13 April 1981 terlihat pada Tabel 4-3.

**Tabel 4-3 : Hasil Prakiraan Anomali OLR Data Lima Harian 17 Juni 1980 sampai 13 April 1981 Posisi 100° BT**

No	PENTAD	$Z_t$	$\hat{Z}_t$	$a_t$
1	19800617	0,26	0,46	-0,20
2	19800622	-0,65	-0,09	-0,56
3	19800627	-0,72	-0,78	0,06
4	19800702	-0,88	-0,24	-0,64
5	19800707	-0,04	-0,52	0,48
6	19800712	-0,01	0,51	-0,52
7	19800717	-0,25	-0,13	-0,12
8	19800722	0,06	-0,22	0,28
9	19800727	-0,11	0,24	-0,35
10	19800801	-0,29	-0,21	-0,08
.	.	.	.	.
.	.	.	.	.
.	.	.	.	.

57	19810324	-0,34	0,50	-0,84
58	19810329	-2,13	-1,35	-0,78
59	19810403	-2,89	-1,71	-1,18
60	19810408	-1,72	-1,58	-0,14
61	19810413	0,93	-0,03	0,96



**Gambar 4-8 :** Plot Data Asli dan Prakiraan Hasil Forecasting Tanggal 17 Juni 1980 sampai Tanggal 13 April 1981 Posisi 100 BT


Gambar 4-8 memperlihatkan pola data prakiraan mendekati pola data asli, akan tetapi data OLR mempunyai pola musiman yang menyebabkan data menjadi tidak stasioner. Untuk menghilangkan pola musimannya, sehingga data menjadi lebih stasioner maka akan dilakukan pembedaan pertama, yaitu :

$$y_t = z_t - z_{t-1}$$

Berikut ini adalah deskriptif statistik data asli, plot data pembedaan pertama dan deskriptif statistiknya.

**Tabel 4-4 :** Deskriptif Statistik Data Asli OLR Posisi 100° BT

	Statistic
Posisi_100BT Mean	.0007
Median	.0000
Variance	1.094
Std. Deviation	1.04573
Minimum	-3.04
Maximum	2.41




**Gambar 4-9 :** Plot Posisi 100° BT Perbedaan Pertama


**Tabel 4-5 :** Deskriptif Statistik Data OLR Posisi 100° BT Perbedaan Pertama

		Statistic
Beda1_100BT	Mean	.0023
	Median	-.0300
	Variance	.874
	Std. Deviation	.93497
	Minimum	-2.76
	Maximum	2.72

Hasil pembedaan pertama ternyata lebih baik, terlihat dari gambar plot data lebih stasioner dan nilai variansinya lebih kecil dari data asli. Melalui plot ACF dan PACF data asli yang dilakukan pembedaan pertama, akan ditentukan model sementara data OLR posisi 100° BT tanggal 3 Januari 1978 sampai 12 Juni 1980.



**Gambar 4-10 :** Fungsi Autokorelasi Data Anomali OLR Posisi 100° BT Perbedaan Pertama



**Gambar 4-11** : Fungsi Autokorelasi Parsial Data Anomali OLR Posisi 100° BT Pembedaan Pertama

Gambar 4-10 memperlihatkan bahwa ACF signifikan pada lag 1, 2, 3 dan 4. Namun karena signifikansi pada lag 2, 3 dan 4 bukan merupakan suatu pengulangan, tapi lebih merupakan random, maka model yang mencerminkan Gambar 4-1 bisa disederhanakan menjadi model moving average orde 1 (MA (1)).

Gambar 4-11 memperlihatkan bahwa PACF terpotong pada banyak lag, tetapi lag pertama dan kedua yang terlihat lebih signifikan, sedangkan lag yang lainnya merupakan suatu pengulangan saja. Dengan demikian model sementara dari plot data OLR posisi 100° BT adalah campuran dari autoregresif, pembedaan pertama dan moving average atau model ARIMA  $(p, 1, q)$ . Dengan nilai  $p$  adalah 1 dan 2, sedangkan nilai  $q$  dipilih 1.

Seperti telah dijelaskan di atas bahwa salah satu cara yang mendasar untuk mendapatkan parameter adalah dengan mencoba-coba (*trial and error*), yaitu menguji beberapa nilai berbeda dan memilih satu nilai yang meminimumkan jumlah kuadrat nilai galat, maka diperoleh satu nilai parameter yang tepat, yaitu parameter dengan model ARIMA(2,1,1) pada Tabel 4-6 berikut ini.

**Tabel 4-6:** Parameter  $\phi_1, \phi_2$  dan  $\theta_1$  untuk Model ARIMA(2,1,1)

		Estimates	Std Error	t	Approx Sig
Non-Seasonal	AR1	.955	.061	15.779	.000
Lags	AR2	-.582	.060	-9.711	.000
	MA1	.995	.096	10.324	.000
Constant		.003	.002	2.140	.034

Dengan koefisien :

$$\phi_1 = 0.955$$

$$\phi_2 = -0.582$$

$$\theta_2 = 0.995$$

Maka model ARIMA(2,1,1) menjadi


$$\hat{Z}_t = 1.955Z_{t-1} - 1.537Z_{t-2} + 0.582Z_{t-3} - 0.995a_{t-1} \quad (4.2)$$

Dengan menggunakan model ARIMA(2,1,1) pada persamaan 4.2 akan diperoleh nilai prakiraan. Lebih jelasnya perbandingan data asli, nilai prakiraan dan nilai galat terlihat pada Tabel 4-7.


**Tabel 4-7 :** Perbandingan Data Asli, Nilai Prakiraan dan Nilai galat OLR Posisi 100° BT

No	PENTAD	$Z_t$	$\hat{Z}_t$	$a_t$	$a_t^2$
1	19780103	-0,16	-	-	-
2	19780108	1,1	-	-	-
3	19780113	1,03	-	-	-
4	19780118	-1,73	0,23	-1,96	3,84
5	19780123	-2,12	-2,38	0,26	0,07
6	19780128	-0,94	-1,14	0,20	0,04
7	19780202	0,87	0,21	0,66	0,43
8	19780207	2,41	1,26	1,15	1,32
9	19780212	0,65	1,68	-1,03	1,07
10	19780217	-0,07	-0,90	0,83	0,69
.	.	.	.	.	.
.	.	.	.	.	.
.	.	.	.	.	.
175	19800523	-0,32	-0,12	-0,20	0,04
176	19800528	0	-0,44	0,44	0,19
177	19800602	-0,05	0,15	-0,20	0,04
178	19800607	0,08	-0,08	0,16	0,03
179	19800612	0,51	0,07	0,44	0,19
	JKG				82,66


Plot nilai galat, ACF dan PACF terlihat pada gambar berikut.




**Gambar 4-12 :** Plot Nilai Galat



**Gambar 4-13 : Fungsi Autokorelasi Nilai Galat**



**Gambar 4-14 : Fungsi Autokorelasi Parsial Nilai Galat**



**Gambar 4-15 : Histogram Nilai Galat**

Gambar 4-13 dan Gambar 4-14 memperlihatkan tidak adanya lagi autokorelasi dan autokorelasi parsial yang signifikan. Gambar 4-15 memperlihatkan bahwa nilai galat berdistribusi normal dengan mean disekitar nol yaitu 0.0915 dan Tabel 4-7 memperlihatkan bahwa jumlah kuadrat nilai galat data OLR posisi  $100^{\circ}$  BT sebesar 82.66. Ini berarti semua asumsi dalam uji diagnostik sudah memenuhi, sehingga persamaan 4.2 bisa digunakan dalam langkah selanjutnya yaitu memprakirakan besarnya anomali OLR pada lima harian berikutnya.

Dari model yang telah didapat pada persamaan 4.2, maka diperoleh prakiraan untuk tanggal 17 Juni 1980 adalah sebagai berikut

$$\hat{Z}_t = 1.955Z_{t-1} - 1.537Z_{t-2} + 0.582Z_{t-3} - 0.995a_{t-1}$$

$$\hat{Z}_{180} = 1.995Z_{179} - 1.537Z_{178} + 0.582Z_{177} - 0.995a_{t-1}$$


$$\hat{Z}_{180} = 1.955(0.51) - 1.537(0.08) + 0.582(-0.05) - 0.995(0.44)$$

$$\hat{Z}_{180} = 0.41$$

Prakiraan lima harian dari tanggal 17 Juni 1980 sampai tanggal 13 April 1981 terlihat pada Tabel 4-8

**Tabel 4-8 :** Hasil Prakiraan Anomali OLR Data Lima Harian 17 Juni 1980 sampai 13 April 1981 Posisi 100° BT


No	PENTAD	$Z_t$	$\hat{Z}_t$	$a_t$
1	19800617	0,26	0,41	-0,15
2	19800622	-0,65	-0,08	-0,57
3	19800627	-0,72	-0,81	0,09
4	19800702	-0,88	-0,35	-0,53
5	19800707	-0,04	-0,46	0,42
6	19800712	-0,01	0,44	-0,45
7	19800717	-0,25	-0,03	-0,22
8	19800722	0,06	-0,27	0,33
9	19800727	-0,11	0,16	-0,27
10	19800801	-0,29	-0,18	-0,11
.	.	.	.	.
.	.	.	.	.
.	.	.	.	.
57	19810324	-0,34	0,49	-0,83
58	19810329	-2,13	-1,41	-0,72
59	19810403	-2,89	-1,85	-1,04
60	19810408	-1,72	-1,54	-0,18
61	19810413	0,93	0,02	0,91




**Gambar 4-16 :** Plot Data Asli dan Prakiraan Hasil Prakiraan Tanggal 17 Juni 1980 sampai Tanggal 13 April 1981 Posisi 100° BT

Dari Gambar 4-16 dapat dilihat bahwa plot data prakiraan mendekati data asli, dengan korelasi sebesar 0.564 atau 56.4 %. Seiring dengan berjalannya waktu akan diketahui data baru, dan tentu saja data baru tersebut bisa digunakan untuk memperbaharui model dengan harapan akan meningkatkan ketepatan dalam prakiraan selanjutnya.

Sebenarnya Model ARMA (2,1) menghasilkan Jumlah Kuadrat Galat (JKG) yang lebih kecil dibandingkan dengan Jumlah Kuadrat Galat (JKG) pada Model ARIMA (2,1,1). Akan tetapi pada kenyataannya data OLR (Radiasi Gelombang Panjang) mempunyai pola musiman yang menyebabkan data tidak stasioner. Dengan demikian, kami memilih model ARIMA (2,1,1) merupakan model yang paling cocok atau sesuai untuk data time-series OLR 100° BT. Dengan teknik yang sama, kami mendapatkan bahwa model ARIMA (2,1,1), juga merupakan model yang cocok atau sesuai untuk data time-series OLR 120° BT, sementara model ARIMA (1,1,2) merupakan model data time-series yang paling sesuai untuk data OLR 140° BT seperti terlihat jelas pada Gambar 4-17 dan Gambar 4-18 berikut.



**Gambar 4-17 :** Sama dengan Gambar 4-16, tetapi untuk data time-series OLR 120° BT



**Gambar 4-18:** Sama dengan Gambar 4-16, tetapi untuk data time-series OLR 140° BT

## 5. KESIMPULAN DAN SARAN

### 5.1. Kesimpulan

Berdasarkan hasil analisis di atas, dapat disimpulkan bahwa melalui metode Box-Jenkins, model yang mendekati untuk data deret waktu anomali OLR (*Outgoing Longwave Radiation*) dari tanggal 3 Januari 1978 sampai tanggal 13 April 1981 pada masing- masing posisi adalah:

- Untuk posisi 100° BT model yang mendekati adalah ARIMA (2,1,1), artinya prakiraan data pentad OLR pada waktu mendatang tergantung dari dua waktu sebelumnya yang telah dibedakan dan galat satu waktu sebelumnya.
- Untuk posisi 120° BT model yang mendekati adalah ARIMA (2,1,1), artinya prakiraan data pentad OLR pada waktu mendatang tergantung dari dua waktu sebelumnya yang telah dibedakan dan galat satu waktu sebelumnya.



- c. Untuk posisi  $140^\circ$  BT model yang mendekati adalah ARIMA (1,1,2), artinya prakiraan data pentad OLR pada waktu mendatang tergantung dari satu waktu sebelumnya yang telah dibedakan dan galat dua waktu sebelumnya.

## **5.2. Saran**

- a. Dalam makalah ini belum diperhitungkan faktor-faktor yang mempengaruhi besarnya anomali OLR. Oleh karena itu, kedepannya nanti disarankan untuk memperbaiki model dengan melakukan studi lebih jauh lagi dengan melibatkan faktor-faktor yang mempengaruhi, seperti besar kecilnya liputan awan (cloud cover) pada posisi  $100^\circ$  BT,  $120^\circ$  BT, dan  $140^\circ$  BT agar diperoleh model yang lebih baik lagi.
- b. Untuk meningkatkan ketepatan dalam prakiraan selanjutnya, sebaiknya model diperbaharui dengan data baru yang diperoleh.
- c. Software yang digunakan pada skripsi ini adalah SPSS 13.0. Kami menyarankan untuk menggunakan *software-software* lain yang lebih aplikatif seperti SAS atau MATLAB.

## **DAFTAR RUJUKAN**

Cryer, J. 1986. *Time Series Analysis*. USA: PWS Publisher.

Makridakis, S., Wheelwright, S. C. and Mcgee, V. E. 1999. *Metode dan Aplikasi Peramalan*, Jilid Satu, Edisi Kedua. Jakarta: Erlangga.

Wei, W. W. S. 1994. *Time Series Analysis, Univariate and Multivariate Methods*. Toronto: Addison Wesley Publisher.

[http:// www.icesb.ucsb.edu/esrg/IOMZ/OLR.html](http://www.icesb.ucsb.edu/esrg/IOMZ/OLR.html), diakses 30 Agustus 2006.

[http:// www.dkp.go.id/images/IMG\\_78.jpg](http://www.dkp.go.id/images/IMG_78.jpg), diakses 30 Agustus 2006.

[http:// www.cdc.noaa.gov/map/images/olr/olr.month.gif](http://www.cdc.noaa.gov/map/images/olr/olr.month.gif), diakses 30 Agustus 2006.

[www.cpc.noaa.gov/products/precip/CWLink/daily\\_mjo\\_index/proj\\_norm\\_order.asc](http://www.cpc.noaa.gov/products/precip/CWLink/daily_mjo_index/proj_norm_order.asc)ii  
diakses 30 Mei 2006.